

INFO-1009

Primljeno/Received 2007-03-20

UDK: 007:659.3:658.7

Pregledni rad / Author Review

# MARKETING INFORMACIJSKI SUSTAVI ZA OTKRIVANJE PREFERENCIJA POTROŠAČA U PROCESU DONOŠENJA ODLUKA O KUPOVINI

## MARKETING INFORMATION SYSTEM FOR DISCOVERING CONSUMER PREFERENCES IN THE PURCHASE DECISION MAKING PROCESS

*Brano Markić, Slavo Kukić, Dražena Tomić*

Ekonomski fakultet, Sveučilište u Mostaru, Mostar, Bosna i Hercegovina  
Faculty of Economy, University of Mostar, Mostar, Bosnia and Herzegovina

### *Sažetak*

Spoznati preferencije potrošača je složen istraživački zadatak. Proces izbora nekog proizvoda i njegova kupovina temelji na većem broju dimenzija, kriterija i faktora koji konvergiraju u svijesti potrošača u trenutku kupovine. Zato je poseban istraživački zadatak je otkriti što potrošač ocjenjuje u procesu izbora proizvoda, koja njegova svojstva i obilježja. U radu se polazi od pretpostavke da kupac uvijek postavlja određene kriterije i na temelju subjektivne procjene njihovih relativnih važnosti donosi odluku i bira određenu alternativu. Kompleksnost odluke i napor potrošača je izravno proporcionalan iznosu novca potrebnog za kupovinu. Ipak, proces kupovine je izomorfan u odnosu na proizvod koji se kupuje. Drugim riječima, proces kupovine slijedi određene zakonitosti i logiku neovisnu o predmetu kupovine. Pretpostavka je da se kupovina temelji na vrednovanju različitih kriterija i alternativa. Zato je nužno prikupiti veliki broj podataka, obaviti složene obrade nad tim podacima i spoznati preferencije potrošača. Takav istraživački zadatak je moguće obaviti samo izgradnjom odgovarajućeg marketing informacijskog sustava za potporu odlučivanju.

### *Abstract*

Discovering consumer preferences is complex research task. It is remarkable the product selection process and it purchase is based on multiple dimensions, criteria and factors which converge in the consumer conscious at the purchase moment. In the paper is proposed that the consumer always sets some criteria and using relative importance their subjective assessments, makes decisions and selects some alternative. The process of purchase is isomorphic to product. With another words the purchasing process follows some rules and regularities independent on product of purchase. We suppose that the purchase is based on evaluation more criteria and alternatives. Because is necessary to collect a huge number of data, perform complex calculations on data and get the knowledge about consumer preferences. Such research task is possible complete only building up of adequate marketing decision support system.

### **1. Uvod**

Informacijski sustav čine "skup ljudi i opreme" povezanih aktivnostima prikupljanja, obrade, pohranjivanja i distribucije podataka i informacija, s krajnjim ciljem generiranja informacija u različitim problemskim situacijama i na različitim razinama organiziranosti nekog objektnog sustava vodeći računa o temeljnim ekonomskim načelima /1/. Takav se cilj ne može jednostavno realizirati u praksi. Svaki informacijski sustav ima pet elemenata hardver, softver, podatke (informacije), procese i ljude. Cilj rada je izgraditi marketing

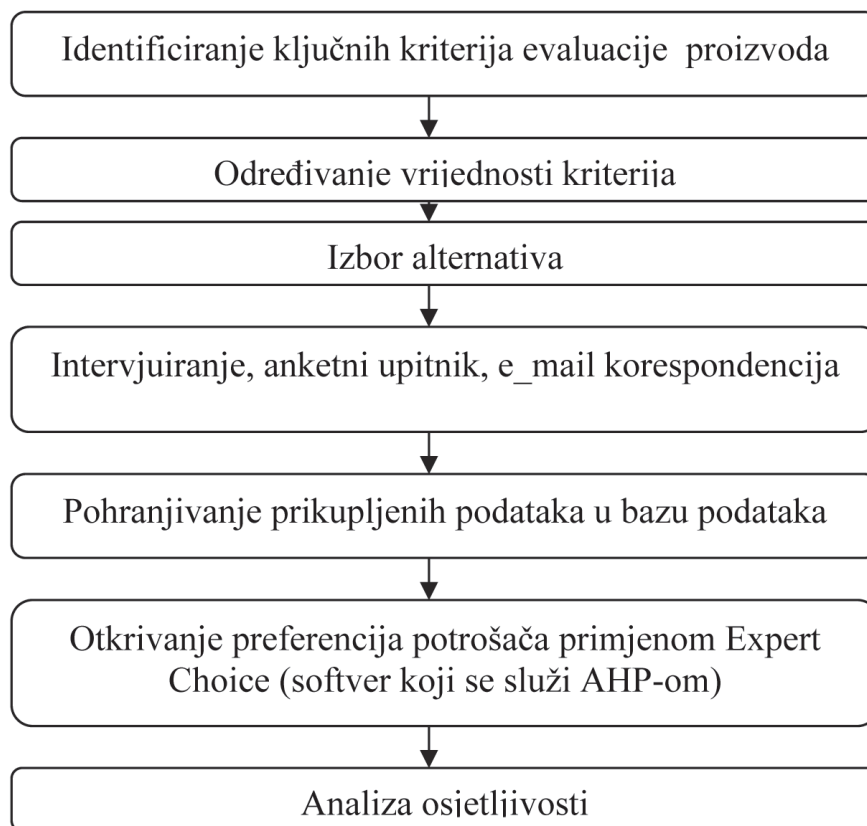
informacijski sustav za potporu odlučivanju koji će pomoći u otkrivanju preferencija potrošača. Zato su potrebni sofisticirani softveri za kompleksne analize, interpretacije, dijagnoze poslovnih situacija kao i predviđanje budućih kretanja i promjena. Ti sustavi su veoma fleksibilni, a menadžeri ih primjenjuju na strategijskoj razini u rješavanju nestrukturiranih problema odlučivanja. "Oslanjaju" se na podatke transakcijskih informacijskih sustava ili na spremišta podataka (data warehouse) i pomažu menadžerima u sagledavanju trendova i utjecaja vanjskih događaja na ponašanje, rast i razvoj organizacije. Jedna od ključnih komponenti

svakog informacijskog sustava su podaci. Podaci za marketing informacijski sustav se nalaze u bazama podataka unutar poduzeća (u njima se čuvaju podaci o proizvodima, kupcima, dobavljačima, prodanim količinama), bazama podataka izvan organizacije, te specifičnim bazama podataka koje čuvaju podatke o odgovorima na postavljena pitanja kupcima u anketnom upitniku.

## 2. Podaci

Podaci marketing informacijskog sustava za otkrivanje preferencija potrošača su prikupljeni iz više izvora: nestrukturiranim intervjuima, upitnikom, e-mail korespondencijom te podacima unutar baze podataka poduzeća /2/.

Organizacija istraživanja se temelji na više sekvencijalnih koraka prikazanih na sljedećoj slici:



Slika 1. Tijek istraživanja preferencija potrošača

Prvi korak u istraživanju je doznati koje kriterije kupac „prerađuje“ u svojoj memoriji i odabire marku. Istraživanje se koncentrira na marke pet proizvođača kemijskih olovki: Pilot, Parker, Uni, TOZ, Staedler. Nakon niza intervju s kupcima izabrana su tri dominantna kriterija: odnos cijena/performansa, dizajn proizvoda i reputacija proizvođača. Vrijednosti svih kriterija su određene kvalitativno. Primjenjuje se ordinalna ljestvica koja pridružuje vrijednostima kriterija (kvalitativnim podacima) brojeve (slovne oznake), *prema stupnju* (intenzitetu) svojstva. Stupanj tih razlika nije bitan ali se vrijednosti kvalitativnih obilježja mogu urediti

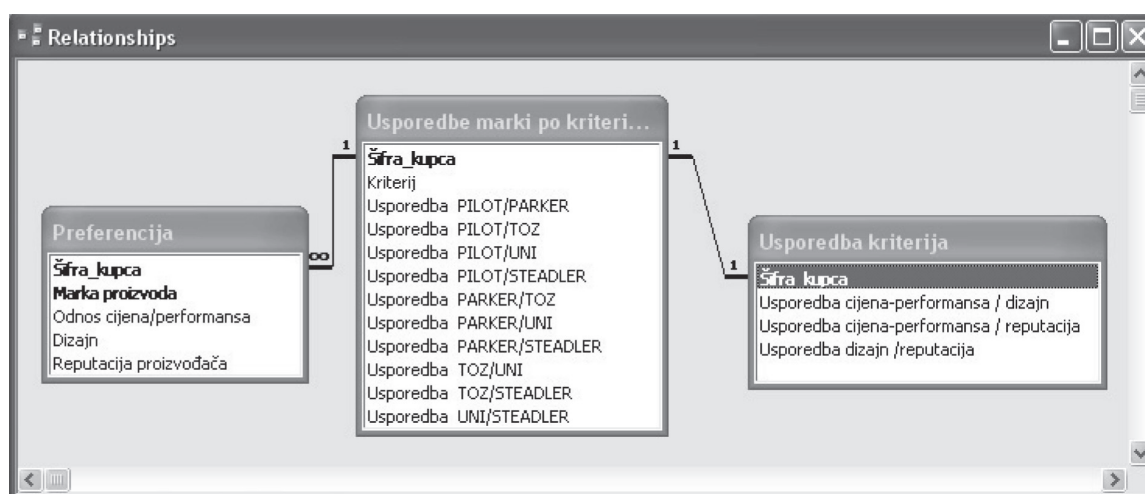
prema nekom redoslijedu. Vrijednosti kriterija odnos cijena/performansa su: zadovoljavajući, dobar, izvrstan; vrijednosti kriterija dizajn su: rang 1, rang 2, rang 3 (vrijednosti su uređene u rastućem redoslijedu); vrijednosti kriterija reputacija proizvođača su: dobra, velika, izvrsna.

Skup alternativa (Pilot, Parker, Uni, TOZ, Staedler) je jednoznačno određen. To su marke proizvoda i cilj je spoznati preferencije potrošača prema tim markama. Sljedeći korak je unosenje podataka dobivenih odgovorima u upitniku. Ti odgovori su unijeti u bazu podataka koju čini tablica sljedećeg izgleda:

Preferencija : Table								
	Šifra_kupca	Marka proizvoda	Odnos cijena/performansa	Dizajn	Reputacija proizvođača			
	1	PARKER	Dobar	Rang 3	Velika			
▶	1	PILOT	Zadovoljavajući	Rang 1	Dobra			▼
	1	STEADLER	Izvrstan	Rang 2	Dobra			
	1	TOZ	Zadovoljavajući	Rang 1	Dobra			
	1	UNI	Dobar	Rang 2	Dobra			
	2	PARKER	Izvrstan	Rang 3	Izvrсна			
	2	PILOT	Dobar	Rang 2	Velika			
	2	STEADLER	Izvrstan	Rang 2	Velika			
	2	TOZ	Zadovoljavajući	Rang 2	Dobra			
	2	UNI	Dobar	Rang 2	Dobra			
	3	PARKER	Izvrstan	Rang 3	Izvrсна			
	3	PILOT	Dobar	Rang 2	Velika			
	3	STEADLER	Izvrstan	Rang 2	Izvrсна			
	3	TOZ	Zadovoljavajući	Rang 2	Dobra			
	3	UNI	Zadovoljavajući	Rang 3	Dobra			
	4	PARKER	Izvrstan	Rang 3	Izvrсна			
	4	PILOT	Dobar	Rang 3	Velika			

Slika 2. Odgovori kupaca na pitanja iz upitnika unijeti u relacijsku tablicu

Logički model podataka uključuje još dvije tablice: Usporedbe marki (alternativa) po kriterijima i međusobne usporedbe svaka dva kriterija.



Slika 3. Logički model baze podataka za otkrivanje preferencija potrošača

Usporedbi alternativa  $a_i$  i  $a_j$  u odnosu na kriterij  $c_k$  potrošač pridružuje broj  $x_{ij}/3$ :

1.  $x_{ij}=1$  ako su  $a_i$  i  $a_j$  **jednako** preferirane
2.  $x_{ij}=3$  ako alternativa  $a_i$  i ima **slabu** prednost u odnosu na  $a_j$
3.  $x_{ij}=5$  ako alternativa  $a_i$  i ima **jaku** prednost u odnosu na  $a_j$
4.  $x_{ij}=7$  ako alternativa  $a_i$  i ima **vrlo jaku** prednost u odnosu na  $a_j$

5.  $x_{ij}=9$  ako alternativa  $a_i$  i ima **apsolutnu** prednost u odnosu na  $a_j$

Uspoređivanje po parovima mora zadovoljiti dva načela: recipročnost i homogenost. Recipročnost znači da jačina prioriteta zadovoljava uvjet  $x_{ij}=1/x_{ji}$ . Homogenost povećava preciznost procjena jer uvodi i među vrijednosti 2, 4, 6 i 8.

Na sljedećoj slici prikazani su odgovori kupaca tj. njihove subjektivne procjene relativne važnosti jednog u odnosu na drugi kriterij.

Usporedba kriterija : Table			
	Šifra_kupca	Usporedba cijena-performansa / dizajn	Usporedba cijena-performansa / reputacija
+	1	5 - jaka prednost prvog	7 - vrlo jaka prednost prvog
+	2	7 - vrlo jaka prednost prvog	9 - apsolutna prednost prvog
+	3	5 - jaka prednost prvog	7 - vrlo jaka prednost prvog
+	4	5 - jaka prednost prvog	7 - vrlo jaka prednost prvog
+	5	5 - jaka prednost prvog	5 - jaka prednost prvog
+	6	7 - vrlo jaka prednost prvog	7 - vrlo jaka prednost prvog

Slika 4. Odgovori kupaca temeljeni na međusobnoj usporedbi dva kriterija

Na temelju odgovora kupaca pohranjenim u bazi podataka moguće je izgraditi tablicu odlučivanja preračunavanjem vrijednosti danih odgovora svih promatranih kupaca. Izračunavaju se prosječne vrijednosti stupaca u tablici Usporedba kriterija i Usporedbe marki po kriterijima. Strategija izbora procesuiranjem marke i obilježja proizvoda /4/ se u sljedećem koraku transformira u hijerarhijsku strukturu koja čini suštinu analitičkog hijerarhijskog procesa.

### 3. Izgradnja modela preferencija potrošača

Nakon prikupljanja potrebnih podataka i izgradnje modela baze podataka potrebno je u skladu s zahtjevima analitičkog hijerarhijskog procesa (modela odlučivanja) u obliku tablica prikazati rezultate obrade podataka u bazi. U našem modelu baze sve se međusobne usporedbe kriterija i usporedbe alternativa sa svim kriterijima nalaze u

tablicama Usporedba kriterija i Usporedbe marki po kriterijima. Za svaki stupac tablice Usporedba kriterija i i Usporedbe marki po kriterijima se izračunava prosječna vrijednost i zaokružuje na cijeli broj čije se značenje potom očitava na ranije prikazanoj Saatijevoj skali. Dovoljan je samo jedan jednostavan SQL upit:

```
SELECT Avg([Numericki Usporedba
Kriterija].[Usporedba cijena-performansa / dizajn])
AS ["Cijena-performansa i dizajn"], Avg([Numericki
UsporedbaKriterija].[Usporedbacijena-performansa
/ reputacija]) AS ["Cijena-performansa i reputacija"],
Avg([Numericki Usporedba Kriterija].[Usporedba
dizajn /reputacija]) AS ["Dizajn i reputacija"]
```

FROM [Numericki Usporedba Kriterija];

Rezultat primjene takva SQL upita su prosječne vrijednosti odnosa kriterija cijena/performansa i dizajn, cijena/performansa i reputacija, dizajn i reputacija:

	"Cijena-performansa i dizajn"	"Cijena-performansa i reputacija"	"Dizajn i reputacija"
►	5,66	7	0,25

Slika 5. Prikaz subjektivnih procjena potrošača o relativnoj važnosti kriterija u obliku tablice

Rezultat tog upita ćemo prikazati u obliku matrice kriterija tj. matrice koja odražava subjektivne procjene potrošača o relativnoj važnosti kriterija.

Rezultati se prikazuju u obliku dvodimenzijskih pivot tablica pomoću softvera Expert Choice (Sl. 6.).

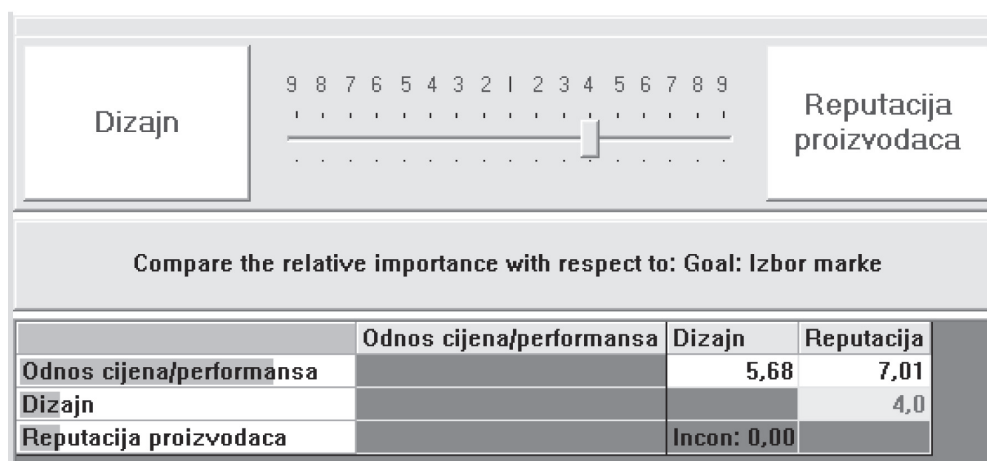
Izračunate prosječne vrijednosti odnosa između kriterija unesene su u softver Expert Choice i prikazane u obliku matrice. Tako su potrošači odnos između kriterija cijena/performansa i dizajn vrjednovali prosječno s 5,6 tj. na Saatyevoj ljestvici /5/ je to među vrijednost između jake ( $x_{ij}=5$ ) i vrlo jake ( $x_{ij}=7$ ) prednosti cijene/performanse u odnosu na dizajn. Odnos između kriterija dizajn i reputacija proizvođača je 1:4 (u tablici sa slike 5 vrijednost 0,25) je u tablici (Slika 6.) prikazan kao 4 i obojen je crvenom bojom. Crvena boja znači da je na Saatyevoj ljestvici dana prednost reputaciji proizvođača u odnosu na dizajn s  $x_{32}=4$  (tj.  $x_{23}=1/4=0,25$ ).

Primijenimo li postupak za približno računanje vrijednosti težina kriterija (ponovno se služeći Expert Choice-om) kao rezultat dobijemo slijedeće vrijednosti težina kriterija:

**Odnos cijena/performansa** ,743  
**Reputacija proizvođača** ,180  
**Dizajn** ,077  
**Inconsistency = 0,28**

Faktor inkonzistencije je 0,28 i on prelazi prihvatljivu vrijednost 0,10. Međutim inkonzistencija je rezultat odgovora potrošača i prihvaćamo je u daljem radu /6/.

Iz vrijednosti težina kriterija je vidljivo da se najveća važnost daje kriteriju cijena/performansa ( $w_1=0,743$ ), potom reputaciji proizvođača ( $w_2=0,18$ ) i na koncu dizajnu ( $w_3=0,077$ ).



Slika 6. Subjektivne procjene potrošača odnosa između kriterija

Isti algoritam se primjenjuje za procjenu omjera prioriteta (preferencija) marke po kriteriju cijena/performansa. Iz tablice Usporedba marki po

kriterijima za svaki stupac se izračunava prosječna vrijednost i te vrijednosti se unose u dvodimenzijske Pivot tablica pomoću softvera Expert Choice:

	PARKER	PILOT	STEADLER	TOZ	UNI
PARKER		1,77	1,48	3,72	3,39
PILOT			1,53	4,99	1,09
STEADLER				3,33	3,85
TOZ					1,41
UNI		Incon: 0,08			

Slika 7. Prioriteti alternative po kriteriju cijena/performansa

Izbor marki s normaliziranim vrijednostima s obzirom na cijena/performansa:	Vektor preferencija potrošača s obzirom na kriterij cijena/performansa:
PILOT 1,000	PILOT ,301
STEADLER ,934	STEADLER ,281
PARKER ,774	PARKER ,233
UNI ,392	UNI ,118
TOZ ,223	TOZ ,067

	PARKER	PILOT	STEADLER	TOZ	UNI
PARKER		1,5	1,26	4,58	3,98
PILOT			2,03	5,07	5,28
STEADLER				2,95	2,05
TOZ					1,66
UNI		Incon: 0,02			

Slika 8. Prioriteti alternative po kriteriju dizajn

Izbor marki s normaliziranim vrijednostima s obzirom na dizajn:	Vektor preferencija potrošača s obzirom na kriterij dizajn:
PILOT 1,000	PILOT ,333
PARKER ,995	PARKER ,331
STEADLER ,573	STEADLER ,191
UNI ,251	UNI ,084
TOZ ,186	TOZ ,062




	PARKER	PILOT	STEADLER	TOZ	UNI
PARKER		2,93	3,17	5,19	5,56
PILOT			2,09	3,09	2,58
STEADLER				2,76	2,17
TOZ					2,98
UNI		Incon: 0,06			

Slika 9. Prioriteti alternative po kriteriju reputacija proizvođača

Izbor marki s normaliziranim vrijednostima s obzirom na reputaciju proizvođača:		Vektor preferencija potrošača s obzirom na kriterij reputacija potrošača:
<b>PARKER</b>	1,000	<b>PARKER</b> ,459
<b>PILOT</b>	,471	<b>PILOT</b> ,216
<b>STEADLER</b>	,283	<b>STEADLER</b> ,130
<b>TOZ</b>	,228	<b>TOZ</b> ,104
<b>UNI</b>	,198	<b>UNI</b> ,091

Na temelju subjektivnih procjena kupaca o relativnom odnosu (omjeru) prioriteta u tablicama 7-9 izračunati su lokalni prioriteti izbora marke. Ukupni prioritet pojedine marke s obzirom na relativnu važnost svih kriterija izračuna se tako

što se lokalni prioriteti ponderiraju s relativnom važnosti kriterija (težinama kriterija) i ti umnoški zbroje. Rezultati preferencija marki proizvoda, sortirani po preferencijama, dani su na sljedećoj slici:




Slika 10. Preferencije potrošača prema marki proizvoda

Izlaz iz marketing informacijskog sustava je informacija da s obzirom na kriterije odnos cijena/performansa, dizajn i reputacija proizvođača 28,8%

potrošača preferira Pilot, 28,1% preferira Parker, 24,7% Uni, 11,1% Uni i 7,3% TOZ.

#### 4. Analiza osjetljivosti


Analiza osjetljivosti ima cilj dati odgovore na pitanje koliko su preferencije potrošača stabilne ili promjenjive s obzirom na promjenu vrijednosti omjera prioriteta kriterija i omjera vrijednosti težina alternativa za pojedinačne kriterije. Taj dio analize je veoma sofisticiran i koristan jer daje potpunu sliku vrijednosti zaključaka o preferenciji potrošača. Sljedeća slika prikazuje koliko su prioriteti alternative: Pilot, Steadler, Parker, Uni, TOZ osjetljivi na promjene težina kriterija cijena/performance (sl. 11.).



Slika 11. Analiza osjetljivosti

Na slici 11. se vidi da prioriteti marki Pilot i Steadler rastu s porastom težine kriterija cijena/performance, prioritet marke Uni se gotovo ne

mijenja dok prioritet marke TOZ blago opada, a prioritet Parkera opada znatno brže.



Slika 12: Analiza osjetljivosti pomoću softvera Expert Choice – opcija Dynamic

Dovoljno je relativnu važnost kriterija cijena/performance s 74,3% umanjiti na 70,5% (težine kriterija dizajn se povećava s 7,7% na 8,8% i težina kriterija reputacija proizvođača s 18% na 20,7%) kako bi se na prvom mjestu preferencija potrošača nalazila marka Parker.

## 5. Zaključak

Rad teorijski i praktično prikazuje integraciju informacijskih tehnologija i problema odlučivanja u marketingu u "otkrivanju" preferencija potrošača. Marketing informacijski sustav pomaže u aktivnostima prikupljanja, pohranjivanja i obrade podataka. Izlaz iz marketing informacijskog sustava su informacija i znanje o ponašanju potrošača. Takva spoznaja omogućuje planiranje prodajnog asortimana, cijena, promocije, kanala distribucije i unapređenja prodaje. U radu je prikazano istraživanje preferencija potrošača prema markama proizvoda na jednom tržišnom segmentu (poslovnom tržištu). Marketing informacijski sustav čuva podatke o rezultatima upitnika, izračunava prosječne vrijednosti kriterija za ocjenjivanje alternativa i subjektivne procjene njihovih odnosa. Analitički hijerarhijski proces omogućuje spoznaju

važnosti alternative (preferencije potrošača) u odnosu na druge alternative. Takva spoznaja omogućuje procjenu relativnog udjela u prodaji pojedinih alternativa (proizvoda) na tom tržišnom segmentu.

### Bilješke

- /1/ Markić, B., (2002), *Poslovna informatika*, HKD Napredak, Mostar.
- /2/ Istraživanje je obavljeno za potrebe poduzeća koje se bavi trgovinom na veliko uredskim materijalima, tonerima, školskim priborom, knjigama.
- /3/ Saaty, T.L., (1980), *The Analytic Hierarchy Process*, McGraw-Hill, New York
- /4/ Kesić, T., (2006), *Ponašanje potrošača*, Opinio, Zagreb.M.I.T. Press.
- /5/ Ibidem /3/
- /6/ Inkonzistencija može biti posljedica nepostojeće ovisnosti među kriterijima ili nedovoljno precizne procjene potrošača.

### Literatura:

1. Aaker, D.A., Kumar, V., Day, G.S.: (2000), *Marketing Research*, John Wiley & Sons, New York.
2. Dyer, D.B.A., Forman Ernest H., (1991) *An Analytical Approach to Marketing decisions*, Prentice Hall, New Jersey.
3. Markić, B., Tomić, D. (2005), *Executive information system for customers clustering*, Društvo i tehnologija, Međunarodni simpozij, Hrvatska, Zadar